IN THE UNITED STATES PATENT AND TRADEMARK OFFICE

Applicant(s):

NAKATANI, et al.

Serial No.:

Not yet assigned

Filed:

January 29, 2004

Title:

STORAGE SYSTEM AND FILE-REFERENCE METHOD OF

REMOTE-SITE STORAGE SYSTEM

Group:

Not yet assigned

LETTER CLAIMING RIGHT OF PRIORITY

Commissioner for Patents P.O. Box 1450 Alexandria, VA 22313-1450 January 29, 2004

Sir:

Under the provisions of 35 USC 119 and 37 CFR 1.55, the applicant(s) hereby claim(s) the right of priority based on Japanese Patent Application No.(s) 2003-364793, filed October 24, 2003.

A certified copy of said Japanese Application is attached.

Respectfully submitted,

ANTONELLI, TERRY, STOUT & KRAUS, LLP

Carl I. Brundidge

Registration No. 29,621

CIB/alb Attachment (703) 312-6600



別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office.

出願年月日 Date of Application:

2003年10月24日

出願番号 Application Number:

特願2003-364793

[ST. 10/C]:

[J P 2 0 0 3 - 3 6 4 7 9 3]

出 願 人

Applicant(s):

株式会社日立製作所

特許庁長官 Commissioner, Japan Patent Office 2003年11月26日





j

【書類名】 特許願 【整理番号】 KN1567

【提出日】平成15年10月24日【あて先】特許庁長官殿【国際特許分類】G06F 12/00

【発明者】

【住所又は居所】 神奈川県川崎市麻生区王禅寺1099番地 株式会社日立製作所

システム開発研究所内

【氏名】 中谷 洋司

【発明者】

【住所又は居所】 神奈川県川崎市麻生区王禅寺1099番地 株式会社日立製作所

システム開発研究所内

【氏名】 北村 学

【特許出願人】

【識別番号】 000005108

【氏名又は名称】 株式会社 日立製作所

【代理人】

【識別番号】 100093492

【弁理士】

【氏名又は名称】 鈴木 市郎 【電話番号】 03-3591-8550

【選任した代理人】

【識別番号】 100078134

【弁理士】

【氏名又は名称】 武 顕次郎 【電話番号】 03-3591-8550

【手数料の表示】

【予納台帳番号】 113584 【納付金額】 21,000円

【提出物件の目録】

【物件名】 特許請求の範囲 1

 【物件名】
 明細書 1

 【物件名】
 図面 1

 【物件名】
 要約書 1



【書類名】特許請求の範囲

【請求項1】

データを記憶する1つ又は複数のディスクドライブ、前記ディスクドライブに対するデータの読み書きを制御するディスク制御部、前記ディスクドライブとのデータ授受に用いられるディスクキャッシュ、を有するディスク装置と、

CPU、前記CPUで実行されるプログラムとデータを格納するメインメモリ、クライアントとネットワークを介して接続されるネットワークインタフェース、を有するファイルサーバと、

通信回線を介して他のストレージシステムのディスク装置とデータを授受するインタフェースと、を備えたストレージシステムであって、

前記メインメモリには、ファイルとディスクドライブ内のデータ位置とが対応するように前記ディスクドライブの領域を管理するファイルシステム処理部と、前記ファイルシステムが使用するファイルシステムキャッシュと、が存在し、

前記ディスク制御部は、前記他のストレージシステムのディスク装置に対して行われたファイルの更新内容とファイルの管理情報履歴とを、前記通信回線を介して前記他のストレージシステムから受信して前記ストレージシステムのディスク装置に格納するように動作し、

前記ストレージシステムのディスク装置に格納されたファイルの管理情報履歴を参照することによって、前記他のストレージシステムで行われたファイル更新に対応して前記ファイルシステムキャッシュ上でファイルの管理情報を更新し、

前記ストレージシステムに接続されたクライアントからの読み出し要求があった場合、 前記ファイルシステムキャッシュ上で更新されたファイルの管理情報を参照してファイル の更新内容を前記クライアントに転送する

ことを特徴とするストレージシステム。

【請求項2】

請求項1において、

前記メインメモリ上のファイルシステム処理部は、前記管理履歴情報であるジャーナルログを参照してファイルの管理情報であるメタデータが更新されたことを監視するメタデータ更新監視部と、

前記メタデータ更新監視部によってファイルの更新を検知して前記ファイルシステムキャッシュのメタデータを更新するメタデータ更新部と、を有する

ことを特徴とするストレージシステム。

【請求項3】

請求項2において、

前記ファイルシステム処理部は、前記メタデータ更新監視部と前記メタデータ更新部に加えて、前記メタデータ更新部でメタデータを更新した場合に前記ファイルシステムキャッシュ内の対応するユーザデータを廃棄するファイルシステムキャッシュパージ部を有する

ことを特徴とするストレージシステム。

【請求項4】

請求項2において、

前記メタデータ更新監視部は、前記ディスクドライブ内のジャーナルログ領域への書き 込みを監視することによってファイル更新を認識する

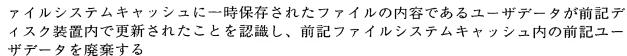
ことを特徴とするストレージシステム。

【請求項5】

請求項3において、

前記メタデータ更新部は、前記ディスクドライブ内のジャーナルログの内容を監視することによって、前記ファイルシステムキャッシュ内に一時保存された前記メタデータを更新し、

前記ファイルシステムキャッシュパージ部は、前記メタデータの更新に対応して前記フ



ことを特徴とするストレージシステム。

【請求項6】

データを記憶する1つ又は複数のディスクドライブ、前記ディスクドライブに対するデータの読み書きを制御するディスク制御部、前記ディスクドライブとのデータ授受に用いられるディスクキャッシュ、を有するディスク装置と、

各種処理を実行するCPU、前記CPUで実行されるプログラムとデータを格納するメインメモリ、クライアントとネットワークを介して接続されるネットワークインタフェース、を有するファイルサーバと、

通信回線を介して他のストレージシステムのディスク装置とデータを授受するインタフェースと、を備えたストレージシステムのファイル参照方法において、

前記メインメモリには、ファイルとディスクドライブ内のデータ位置とが対応するように前記ディスクドライブの領域を管理するファイルシステムの各種処理を行うファイルシステム処理部と、前記ファイルシステムが使用するバッファであるファイルシステムキャッシュと、を設け、

前記ディスク制御部は、前記他のストレージシステムのディスク装置に対して行われたファイルの更新内容とファイルの管理情報履歴とを、前記通信回線を介して前記他のストレージシステムから受信して前記ストレージシステムのディスク装置に格納するように動作するものであり、

前記ストレージシステムのディスク装置に格納されたファイルの管理情報履歴を参照する監視ステップと、

前記管理情報履歴の参照に基づいて前記他のストレージシステムで行われたファイル更新に対応して前記ファイルシステムキャッシュ上でファイルの管理情報を更新する更新ステップと、

前記ストレージシステムに接続されたクライアントからの読み出し要求があった場合、 前記ファイルシステムキャッシュ上で更新されたファイルの管理情報を参照してファイル の更新内容を前記クライアントに転送する転送ステップとからなる

ことを特徴とするストレージシステムのファイル参照方法。

【請求項7】

請求項6において、

前記監視ステップは、前記管理履歴情報であるジャーナルログを参照してファイルの管理情報であるメタデータが更新されたことを監視するメタデータ更新監視ステップであり

前記更新ステップは、前記メタデータ更新監視ステップによってファイルの更新を検知して前記ファイルシステムキャッシュのメタデータを更新するメタデータ更新ステップである

ことを特徴とするストレージシステムのファイル参照方法。

【請求項8】

請求項7において、

前記メタデータ更新監視ステップと前記メタデータ更新ステップに加えて、前記メタデータ更新ステップでメタデータを更新した場合に前記ファイルシステムキャッシュ内の対応するユーザデータを廃棄するファイルシステムキャッシュパージステップ、からなることを特徴とするストレージシステムのファイル参照方法。

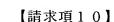
【請求項9】

請求項7において、

前記メタデータ更新監視ステップは、前記ディスクドライブ内のジャーナルログ領域への書き込みを監視することによってファイル更新を認識するステップである

ことを特徴とするストレージシステムのファイル参照方法。

3/



請求項8において、

前記メタデータ更新ステップは、前記ディスクドライブ内のジャーナルログの内容を監視することによって、前記ファイルシステムキャッシュ内に一時保存された前記メタデータを更新するステップであり、

前記ファイルシステムキャッシュパージステップは、前記メタデータの更新に対応して 前記ファイルシステムキャッシュに一時保存されたファイルの内容であるユーザデータが 前記ディスク装置内で更新されたことを認識し、前記ファイルシステムキャッシュ内の前 記ユーザデータを廃棄するステップである

ことを特徴とするストレージシステムのファイル参照方法。

【請求項11】

データを記憶する1つ又は複数のディスクドライブ、前記ディスクドライブに対するデータの読み書きを制御するディスク制御部、前記ディスクドライブとのデータ授受に用いられるディスクキャッシュ、を有するディスク装置と、

各種処理を実行するCPU、前記CPUで実行されるプログラムとデータを格納するメインメモリ、クライアントとネットワークを介して接続されるネットワークインタフェース、を有するファイルサーバと、

通信回線を介して他のストレージシステムのディスク装置とデータを授受するインタフェースと、をそれぞれ備えた第1のストレージシステムと第2のストレージシステムを含む統合システムであって、

前記第1と第2のストレージシステムのメインメモリには、ファイルとディスクドライブ内のデータ位置とが対応するように前記ディスクドライブの領域を管理するファイルシステムの各種処理を行うファイルシステム処理部と、前記ファイルシステムが使用するバッファであるファイルシステムキャッシュと、が存在し、

前記第1のストレージシステムのディスク制御部は、前記第2のストレージシステムのディスク装置に対して行われたクライアントからのファイルの更新内容とファイルの管理情報履歴とを、前記通信回線を介して前記第2のストレージシステムから受信して前記第1のストレージシステムのディスク装置に格納するように動作し、

前記第1のストレージシステムのディスク装置に格納されたファイルの管理情報履歴を 参照することによって、前記第2のストレージシステムで行われたファイル更新に対応し て前記第1のストレージシステムのファイルシステムキャッシュ上でファイルの管理情報 を更新し、

前記第1のストレージシステムに接続されたクライアントからの読み出し要求があった場合、前記ファイルシステムキャッシュ上で更新されたファイルの管理情報を参照してファイルの更新内容を前記第1のストレージシステムに接続されたクライアントに転送可能とする

ことを特徴とする統合ストレージシステム。

【請求項12】

請求項11において、

前記第1のストレージシステムのメインメモリ上のファイルシステム処理部は、前記管理履歴情報であるジャーナルログを参照してファイルの管理情報であるメタデータが更新されたことを監視するメタデータ更新監視部と、

前記メタデータ更新監視部によってファイルの更新を検知して前記ファイルシステムキャッシュのメタデータを更新するメタデータ更新部と、を有する

ことを特徴とする統合ストレージシステム。

【請求項13】

請求項12において、

前記第1のストレージシステムのファイルシステム処理部は、前記メタデータ更新監視 部と前記メタデータ更新部に加えて、前記メタデータ更新部でメタデータを更新した場合 に前記ファイルシステムキャッシュ内の対応するユーザデータを廃棄するファイルシステ ムキャッシュパージ部を有する

ことを特徴とする統合ストレージシステム。

【請求項14】

請求項12において、

前記第1のストレージシステムのメタデータ更新監視部は、前記ディスクドライブ内の ジャーナルログ領域への書き込みを監視することによってファイル更新を認識する ことを特徴とする統合ストレージシステム。

【請求項15】

請求項13において、

前記第1のストレージシステムのメタデータ更新部は、前記ディスクドライブ内のジャーナルログの内容を監視することによって、前記ファイルシステムキャッシュ内に一時保存された前記メタデータを更新し、

前記第1のストレージシステムのファイルシステムキャッシュパージ部は、前記メタデータの更新に対応して前記ファイルシステムキャッシュに一時保存されたファイルの内容であるユーザデータが前記ディスク装置内で更新されたことを認識し、前記ファイルシステムキャッシュ内の前記ユーザデータを廃棄する

ことを特徴とする統合ストレージシステム。

【書類名】明細書

【発明の名称】リモートサイト及び/又はローカルサイトのストレージシステム及びリモートサイトストレージシステムのファイル参照方法

【技術分野】

[0001]

本発明は、地理的に離れた場所に存在する記憶装置の一方でデータの更新が発生した場合に、他方の記憶装置に更新内容を転送することにより、互いのディスクの内容を一致させるリモートコピーに関する。特に、リモートコピーによりコピーされたディスクをファイルシステムで使用するための技術に関する。

【背景技術】

[0002]

一つの場所(ローカルサイト)に存在するディスクドライブの内容が更新された場合、その更新内容を地理的に離れた別の場所(リモートサイト)のディスクドライブに転送し、両サイトのペアを構成するディスクドライブ間でディスクドライブの内容を一致させるストレージのリモートコピーということが知られている(例えば、特許文献1、特許文献2を参照)。

[0003]

これらの特許文献1,2によると、リモートサイトにおいて、リモートコピーされるディスクドライブは待機系として使用され、リモートサイトのディスクドライブは、ローカルサイトがアクセス不能となった場合等に、リモートサイトでマウントしてファイルシステムとして使用することが可能となっている。

【特許文献1】米国特許第6442551号明細書

【特許文献2】特開2003-76592

【発明の開示】

【発明が解決しようとする課題】

$[0\ 0\ 0\ 4]$

従来技術では、リモートコピーのディスクドライブは、ローカルサイトでの障害発生時にフェールオーバ(ローカルサイトでのサービスをリモートサイトに引き継ぐ処理)が発生する等、ペア間のデータ転送の停止(スプリット、例えばペアの解消処理)を行うまでアクセスを行うことが不能であった。例えば、前記特許文献1には、ミラーとして複数のディスクドライブ間のデータを一致させているシステムで、ミラーを解消後にディスクドライブにアクセスを行うことが可能なシステムを提示している。また、前記引用文献2では、リモートコピー機能をもつ記憶装置間で作成されたペアボリュームを、1台の上位装置が前記ペアボリュームを排他的に占有し、他の上位装置からの更新要求を拒否することで、ペアボリュームを複数の上位装置に対して1つのボリュームとして認識させるようにしている。

[0005]

前記特許文献1に示すように、一旦スプリットを行うことが必要な理由は、ペア間のデータ転送を保ったままリモートサイトでディスクドライブをマウントしても、次のような課題があってファイルシステムとして正しくアクセスできないためである。

[0006]

一つの課題は、ディスクのユーザデータをリモートコピーしても、例えば、ジャーナリングファイルシステムの場合、ローカルファイルシステムがメタデータ(詳細は後述するが、ファイルの管理情報)をキャッシュしており、ローカルサイトの記憶装置にも書き出されないため、リモートサイトには更新内容が反映されないことである。

[0007]

他の課題は、リモートサイトのファイルシステム自体もキャッシュを持っているため、 リモートのディスクの内容が更新されても、このキャッシュの内容が更新されないため、 最新のファイルデータが参照されないことである。リモートサイトのファイルシステムが 持つキャッシュに更新前のデータが保持されている場合、ファイルシステムはこのキャッ

2/

シュ内容を使用してしまい、更新前のファイルデータが参照されることとなって、最新のファイルデータが参照されない。

[0008]

本発明の目的は、ローカルサイトでの更新が行われるのに合わせて更新内容をリアルタイムにリモートサイトのファイルシステムに反映させることによって、リモートサイトで最新のファイルデータを参照することのできるストレージシステムを提供することにある

【課題を解決するための手段】

[0009]

前記課題を解決するために、本発明は主として次のような構成を採用する。

データを記憶する1つ又は複数のディスクドライブ、前記ディスクドライブに対するデータの読み書きを制御するディスク制御部、前記ディスクドライブとのデータ授受に用いられるディスクキャッシュ、を有するディスク装置と、

各種処理を実行するCPU、前記CPUで実行されるプログラムとデータを格納するメインメモリ、クライアントとネットワークを介して接続されるネットワークインタフェース、を有するファイルサーバと、

通信回線を介して他のストレージシステムのディスク装置とデータを授受するインタフェースと、を備えたストレージシステムであって、

前記メインメモリには、ファイルとディスクドライブ内のデータ位置とが対応するように前記ディスクドライブの領域を管理するファイルシステムの各種処理を行うファイルシステム処理部と、前記ファイルシステムが使用するバッファであるファイルシステムキャッシュと、が存在し、

前記ディスク制御部は、前記他のストレージシステムのディスク装置に対して行われたファイルの更新内容とファイルの管理情報履歴とを、前記通信回線を介して前記他のストレージシステムから受信して前記ストレージシステムのディスク装置に格納するように動作し、

前記ストレージシステムのディスク装置に格納されたファイルの管理情報履歴を参照することによって、前記他のストレージシステムで行われたファイル更新に対応して前記ファイルシステムキャッシュ上でファイルの管理情報を更新し、

前記ストレージシステムに接続されたクライアントからの読み出し要求があった場合、 前記ファイルシステムキャッシュ上で更新されたファイルの管理情報を参照してファイル の更新内容を前記クライアントに転送可能とする構成である。

【発明の効果】

$[0\ 0\ 1\ 0]$

本発明によれば、リモートコピーを行うストレージシステムにおいて、ローカルサイト での更新が行われるのに合わせて、更新内容をリアルタイムにリモートサイトのファイル システムに反映させ、リモートサイトで最新のファイルデータを参照することができる。

【発明を実施するための最良の形態】

$[0\ 0\ 1\ 1]$

本発明の実施形態に係るストレージシステムについて、図面を参照しながら以下詳細に 説明する。なお、本発明は以下に示す実施形態に限定されるものではない。

$[0\ 0\ 1\ 2]$

図1は本発明の実施形態に係るストレージシステムの全体構成を示すブロック図である。図2は本実施形態のストレージシステムをリモートコピー接続した統合システム構成例を示す図である。図3はローカルサイトとリモートサイトのストレージシステム間でのデータ転送の状況を示す図である。図4は本実施形態で使用するファイルサーバ内のファイルシステム処理部における機能を示す図である。図5はローカルサイトのストレージシステムへのファイル書き込み要求に対するファイル処理部の処理フローを示す図である。図6はストレージシステムのディスク装置に書き込みが行われた場合におけるディスク制御部の実行するリモートコピーの処理フローを示す図である。図7はファイル更新があった

場合のリモートサイトストレージシステムにおけるファイルシステム処理部が実行する複数処理のフローを示す図である。図8はリモートコピーを行う際のリモートサイトに転送されるリモートコピーデータの構成例を示す図である。図9はディスク装置内のディスクドライブに存在するジャーナルログ領域の格納情報を示す図である。

[0013]

図1に示すストレージシステムのブロック図において、ストレージシステム1は、ネットワーク7に接続し、主にファイルの管理を行うファイルサーバ2と、ファイルサーバ2からのデータの入出力要求を処理し、ファイルのデータ等を記憶するための記憶装置であるディスク装置3と、他のストレージシステム1と接続し、主に他のストレージシステム1にデータの送信を行うためのインタフェースであるリモートリンクイニシエータ4(RI)と、他のストレージシステム1からデータの受信を行うためのインタフェースであるリモートリンクターゲット5(RT)と、により構成される。

$[0\ 0\ 1\ 4]$

図1に示す構成例では、ファイルサーバ2がストレージシステム1内部に存在する構成を示したが、ファイルサーバ2がストレージシステム1内部に存在しなくても良い。この場合には、ファイルサーバ2とストレージシステム1との間はファイバチャネル等のインタフェースにより接続されることになる。

$[0\ 0\ 1\ 5]$

ファイルサーバ2は、ネットワーク7に接続するためのネットワークインタフェース12(NI)と、各種処理を実行するCPU11と、CPU11で実行されるプログラムやデータを格納するメインメモリ13と、から構成される計算機である。メインメモリ13上には、CPU11で動作するプログラムであるOS16やファイルシステムの各種処理を行うファイルシステム(以下、FSと称する)処理部17の他、ファイルシステムが使用するバッファであるFSキャッシュ18が存在する。FSキャッシュ18は、ディスク装置3から読み出されたデータや、ネットワーク7を介してクライアント6から書き込まれたデータを一時的に格納する。即ち、FSキャッシュには、ファイルの内容であるユーザデータの他、ファイルの管理情報であるメタデータ(例えば、ファイル名称、ファイルサイズ、データ格納位置、更新日時等)、メタデータの更新履歴であるジャーナルログ(メタデータの経時的な履歴情報)等が格納される。

$[0\ 0\ 1\ 6]$

なお、ファイルシステムはデータをファイルとしてアクセスすることを可能とするものであるが、ファイルシステムの主な仕事はディスクを管理することであり、このアクセスには主にライトとリードがあり、ライトの場合、データの書き込み領域を決定し、その領域に書き込み、領域不足であればディスク空き領域をそのファイル用に割り当てデータ格納する。リードの場合、ディスクのどの領域にファイルの内容が格納されているかを決定し、ディスクからデータを読み出す。このように、データをファイルとしてアクセスさせるということは、ファイルとディスク内のデータの位置の対応を取ることである。

$[0\ 0\ 1\ 7]$

ディスク装置 3 は、ディスク装置の制御を行うディスク制御部 2 1 と、ディスク制御部 2 1 により制御され、ディスクドライブ 2 3 とのデータの受け渡しに使用されるディスクキャッシュ 2 2 と、磁気媒体等で構成されファイルの内容等のデータを記憶するディスクドライブ 2 3 と、により構成される。単体の物理的なディスクドライブのみならず、RAID (Redundant Arrays of Inexpensive Disks)型ディスクアレイのように複数の物理的なディスクドライブを有する場合もある。

[0018]

ディスクキャッシュ22は、ディスク装置3の電源異常が発生した場合でも、内容が消去されることのないように、バッテリーバックアップされた不揮発のメモリによって構成される。ファイルサーバ2からの入出力に応じて、ディスクキャッシュ22上にはデータ格納のための領域(キャッシュエントリ)が確保され、ファイルサーバ2から受け取るデータや、ディスクドライブ23から読み出されたデータが一時保存される。この他に、デ

ィスクキャッシュ22上では、ファイルサーバ2からの書き込みに対して、リモートコピーを行うためのリモートコピーデータの作成や、リモートリンクターゲットRT5を介して他のストレージシステム1から受け取ったリモートコピーデータの一時保存が行われる

[0019]

上述したようなストレージシステムにおいては、ディスク装置に保存されたファイルをアクセスするためには、ファイルの管理情報であり、ファイルのデータ格納位置を有するメタデータを参照しなければならず、そのために、メタデータをディスク装置からFSキャッシュに読み出し、FSキャッシュ上のメタデータを参照することでファイルのアクセスを実行するようになっている。

[0020]

図2に示す統合システム構成例において、ストレージシステム1は、ネットワークインタフェースNI12によりネットワーク7に接続されたクライアント6からのファイルへの処理要求を受け取る。また、リモートリンクイニシエータRI4は地理的に離れた場所に存在するストレージシステム1のリモートリンクターゲットRT5とファイバチャネルによる専用線等の通信回線8で接続される。RI4とRT5の接続は、図2に示すように一台のストレージシステム1が複数のRI4を持ち、複数台のストレージシステム1と接続されていても良いし、一台のストレージシステム1にRI4とRT5を持ち、連鎖状に複数のストレージシステム1を接続しても良い。RI4とRT5で接続されたストレージシステム1間では、事前に双方のディスク装置3内のディスクドライブ23単位でペアを構成する。そして、RI4の存在するストレージシステム1でペアを構成しているディスクドライブ23に対して行われた更新内容は、RT5の持つストレージシステム1に転送され、双方のディスク装置3内のペアを構成するディスクドライブ23間の内容を一致させる。

[0021]

リモートコピーの方式としては、ローカルサイトへの更新と同時に、リモートサイトへの更新内容の転送を行い、転送の完了を待ってからローカルサイトへの更新処理手続を終了する同期方式と、リモートサイトへの転送の完了を待たず、ローカルサイトでの更新処理手続を終了する非同期方式がある。どちらの方式もローカルサイトで行われた更新順序の通りにリモートサイトにデータが転送されて内容が反映される。

[0022]

次に、本発明の実施形態に係る、ローカルサイトとリモートサイトのストレージシステム間でのデータ転送、及びリモートサイトにおける最新ファイルデータの参照の概要について、図3を用いてまず説明する。図3は地理的に離れた場所にあるストレージシステムAとストレージシステムBをリモートリンクイニシエータRIとリモートリンクターゲットRTにより接続した構成図である。図3において、ストレージシステムAにネットワークで接続されたクライアント37からファイルに対して書き込みがあった後、ストレージシステムBにネットワークで接続されたクライアント38から読み出しが行われた場合のデータの流れについて説明する。

[0023]

ローカルサイトのクライアント 37からストレージシステム Aのファイルサーバに対してファイルの書き込み要求が行われ、更新データが転送される(S1)と、ストレージシステム A内の FS 処理部にてローカルサイトの FS キャッシュ 33 内でメタデータ 40 とユーザデータ 41、ジャーナルログ 42 が更新される(S2)。

[0024]

そして、FSキャッシュ内で更新されたデータの内、ユーザデータ43とジャーナルログ44は、同期的にディスク装置内のディスクキャッシュ35に書き込まれる(S3)。その後、リモートコピー部によりリモートコピーデータが作成され、ストレージシステムBに転送される。

[0025]

ストレージシステムB内のディスクキャッシュ36では、リモートコピーされたデータが反映され、ユーザデータ45とジャーナルログ46は、ストレージシステムA内のユーザデータ43とジャーナルログ44と等しい内容に更新される(S4)。ディスクキャッシュ36内でジャーナルログの更新があると、それをメタデータ更新監視部が認識し(後述する図4の説明を参照)、メタデータ更新部がジャーナルログ46をFSキャッシュ上に読み出す(S5)。そして、メタデータ更新部は、読み出したジャーナルログ49を使用してFSキャッシュ内のメタデータ47を更新する(S6)。メタデータが更新されると、FSキャッシュパージ部により更新されたメタデータに対応するFSキャッシュ内のユーザデータを廃棄する。

[0026]

リモートサイトのクライアント38から読み出し要求があった場合には、更新後のメタデータに基づいて、ディスク装置からユーザデータ45が読み出され、FSキャッシュ内に格納される(S7)。そして、クライアント38からの読み出し要求の応答としてユーザデータ48がクライアント38に転送される(S8)。このようにして、ローカルサイトのクライアント37によって書き込まれたファイルの内容が、リモートサイトのクライアント38によって参照される。

[0027]

図3に示す本発明の実施形態に関する、ローカルサイトとリモートサイトのストレージシステム間でのデータ転送及びリモートサイトにおける最新ファイルデータの参照について再度説明する。ストレージシステムにおけるディスク装置内のファイルをアクセスするには、ファイルの管理情報であるメタデータをFSキャッシュ上に読み出してこのメタデータを参照することでファイルのデータ格納位置を取得し、ファイルのアクセスを実行するようなシステムとなっているのである。そして、このシステムを前提とした上で、ロカルサイトのストレージシステムからリモートサイトのストレージシステムにユーザデータをメタデータの更新履歴であるジャーナルログとがリモートコピーによりデータ転送されてきた後に、リモートサイトのストレージシステムに対してクライアントからアクセスがあった場合に、仮に、古いユーザデータ用のメタデータがFSキャッシュ上に残っているとすると、FS(ファイルシステム)処理部はFSキャッシュ上の古いメタデータを終照してファイルにアクセスしようとしてしまうので、ローカルサイトから折角コピーされてきた新しいユーザデータにはアクセスできない(古いデータにはアクセスでも称位置が含まれるので、古いメタデータを参照しても新しいユーザデータにはアクセスできない)と云う解決すべき課題が生じる。

[0028]

そこで、本発明の実施形態では、この課題を解決するために、ローカルサイトのストレージシステムからユーザデータとともに転送されてきたジャーナルログ、即ちファイルの管理情報履歴であるジャーナルログを用いて、リモートサイトのストレージシステムのFSキャッシュ上に新しいメタデータを格納する。更にFSキャッシュに古いユーザデータが残っていると、クライアントからの読み出し要求に応じてFSキャッシュ内の古いユーザデータが読み出されてしまうので、この古いユーザデータをFSキャッシュから廃棄しておく。そして、リモートサイトのクライアントから読み出し要求があれば、FSキャッシュ上の新しいメタデータを参照して新しいユーザデータのファイルにアクセスすることができる。

[0029]

次に、ローカルサイトとリモートサイトのストレージシステム間でのデータ転送における各部署での機能乃至作用について説明する。図8は、リモートコピーを行う際に、ローカルサイトで作成されリモートサイトに転送されるリモートコピーデータの構成例を示す図である。シーケンシャル番号81は、ローカルサイトで更新の行われた順に付けられる番号であり、リモートサイトではこの番号順に自システムに更新内容を反映することによって、ローカルサイトとの更新順序の一致を保証する。データ格納位置82は、ペアを構成しているドライブを識別するための情報と、そのドライブ内での位置を示す情報からな

る。データ83は、ローカルサイトで行われた更新内容であり、この内容がリモートサイトでデータ格納位置82に対応した位置に格納される。

[0030]

図5は、クライアント6からのファイルへの書き込み要求に対するFS(ファイルシステム)処理部17の処理フローを示す。FS処理部17は、ネットワーク7を介して接続されたクライアント6からファイルへの書き込み要求を受信する(ステップ101)。次に、ステップ102では処理を行う対象であるファイルのメタデータがFSキャッシュ18上に存在するかを調べ、存在しない場合はステップ103に進みディスク装置3からメタデータの読み出しを行う。

$[0\ 0\ 3\ 1]$

FS処理部17がファイルに対して処理を行う場合、必要なデータ(ユーザデータおよびメタデータ)がFSキャッシュ18上に存在する必要がある。存在しない場合、上記のようにFS処理部17は、まずディスク装置3からFSキャッシュ18に読み出しを行う。FSキャッシュ18上に読み出されたデータは、一つの処理が終了した後もすぐには捨てられず、FSキャッシュ18上に保持される。それは、その後に行われる処理でデータが必要となった場合は、FSキャッシュ18上のデータを使用することにより効率よく処理を行うためである。

[0032]

FS処理部17は、ステップ103で必要に応じてメタデータの読み出しを行った後、ステップ104で、FSキャッシュ18上で今回の書き込みに対応してメタデータの更新を行う。そして、メタデータの更新と同時に、その更新の内容に対応するジャーナルログを作成し、そのジャーナルログをディスク装置3に書き込む(ステップ105)。

[0033]

ジャーナルログは、図9に示すディスクドライブ23上に存在するジャーナルログ領域90に格納されるログ情報(メタデータの更新履歴情報)である。FS処理部17が行うメタデータの更新の内容をその更新順序どおりにログ情報として記録する。新たなジャーナルログの記録は、終点ポインタ92が示す位置から行い、記録した位置の次に終点ポインタ92を移動させる。始点ポインタ91は、ディスク装置3に更新を行っていないメタデータを含むジャーナルログの開始位置を示すポインタである。FS処理部17は、必要に応じてFSキャッシュ18上のメタデータをディスク装置3に書き込み、始点ポインタ91の位置を進める。即ち、FSキャッシュに存するメタデータを適宜のタイミングでディスクドライブに書き込んでしまえば、その時点で始点ポインタの位置を進ませることができる。始点ポインタ91と終点ポインタ92は、ジャーナルログ領域90内のログデータ領域93を末尾まで移動した次は先頭に移動する。このようにしてラップアラウンドしてログデータ領域93内の場所を指し示す。

$[0\ 0\ 3\ 4]$

そして、始点ポインタ91と終点ポインタ92で囲まれたログデータ領域93内のジャーナルログは、ディスク装置に対して更新内容が未反映のメタデータに対応したジャーナルログが格納された領域を表す。即ち、更新内容の反映したメタデータがディスクドライブに格納されてしまえば、そのメータデータに対応するジャーナルログは始点ポインタと終点ポインタで囲む必要はないのである。

[0035]

ジャーナルログをディスク装置3に書き込むことにより、FS処理部17はメタデータの更新内容をディスク装置3に書き出す処理を、クライアント6に対する処理終了以前に行う必要がなくなる。それは、障害発生によりFSキャッシュ18上のデータが消失されても、ジャーナルログにより消失された内容をディスクドライブから復旧することが可能であるからである。

[0036]

電源断などの障害が発生した場合、FSキャッシュ18上でのみ行われてディスク装置 3に書き出されていないメタデータの更新内容は、FSキャッシュ17上から消失してし まう。障害復旧後にディスク装置3上のメタデータを読み出しても、更新されていないデータである可能性がある。そのため、障害復旧後FS処理部17はディスク装置3からジャーナルログを読み出し、始点ポインタ91と終点ポインタ92で示された領域のジャーナルログの内容を用いることにより、メタデータの内容の更新を行い、障害発生前の最新の状態に復旧することを行う。

[0037]

図5に示すステップ105で、ジャーナルログのディスク装置への書き込み終了後、必要に応じてFSキャッシュ上に領域の確保を行い、ディスク装置3からユーザデータの読み出しを行った後、ディスク制御部21はクライアント6から受け取ったユーザデータをFSキャッシュ18上で更新し(ステップ106)、引き続いて、更新したユーザデータをディスク装置3へ書き込む(ステップ107)。ディスク装置3への書き込み終了後、クライアント6に対して書き込み要求に対する処理の終了応答を返す(ステップ108)

[0038]

上述したように、クライアント6からの書き込み要求に対する処理で、FS処理部17はFSキャッシュ18上でメタデータの更新とジャーナルログの作成とユーザデータの更新を行う。このうち作成されたジャーナルログと更新されたユーザデータは、書き込み要求の終了応答を返す前にディスク装置3に対して書き込みを行う。このようにクライアントからの書き込み要求に対し、更新されたデータをクライアントへの終了応答前にディスク装置3に書き込むことを同期書き込みという。これに対し、メタデータは、FSキャッシュ18上のみ更新しておき、必要に応じて書き込み要求の処理とは無関係(非同期)にディスク装置3に対して書き込みを行うことができる。

[0039]

図5に示すフローは、ユーザデータをディスク装置3へ書き込むステップ107をクライアント6からの書き込み要求と同期して行う場合について示したが、ファイルシステムによっては、クライアントからの書き込み要求ではFSキャッシュ上のユーザデータのみ更新を行い、クライアント6から書き込み要求とは別にコミット要求を受け取り、この時にユーザデータをディスク装置3に書き出すといった処理を行う場合がある。この場合、ユーザデータは書き込み要求とは非同期にディスク装置3に書き込まれることになるが、コミット要求に対しては同期的にディスク装置3に書き込まれる。

[0040]

次に、ディスク装置3に対して書き込みが行われた場合に、ディスク制御部21が行うリモートコピーの処理について説明する。図6はディスク制御部21が行う処理のフローを示す図である。ステップ111でFS処理部17より書き込み要求を受け取ると、ステップ112でディスクキャッシュ22上にデータの書き込みを行う。書き込みが行われると、ディスク制御部内のリモートコピー部26は、ステップ113で、ディスクキャッシュ22上にリモートコピー転送用データの作成を行う。ステップ114では、作成されたデータをリモートリンクイニシエータRI4からリモートサイトにあるストレージスステムにリモートリンクターゲットRT5を通して転送する。そして、ステップ115でリモートサイトのストレージからの受信の応答を待ち、受信を確認後にステップ116で書き込み要求に対する終了の応答をFS処理部17に返す。

[0041]

リモートサイトのストレージシステムでは、RT5を通して受け取ったリモートコピーデータ内の更新データの内容を自システムに反映することで、自システムのファイルサーバ2から読み出し要求(リモートサイトのストレージシステムに接続されたクライアントからのファイルサーバを介した読み出し要求)があった場合に、更新データの内容を返すことができる。更新データの自システムへの反映は、ディスクキャッシュ22上で行われる。ディスク制御部21は、ファイルサーバを介さずに、RT5を通して受け取ったリモートコピーデータのデータ格納位置から、自システム内の対応する格納位置を計算する。そしてその位置に対するエントリをディスクキャッシュ22内に確保し、そこに更新デー

タの内容を書き込む。このようにして、リモートサイト内のディスク装置3では、転送されてきたリモートコピーデータの内容が順次反映され、ローカルサイトで更新された内容と同一の内容がディスク装置3上に保存される。

[0042]

しかし、リモートサイトで、リモートサイトストレージに接続されたクライアントがファイルの参照を行うためには、リモートサイトのFSキャッシュ18の内容をローカルサイトでの更新に対応して更新する必要がある(上述したように、リモートリンクターゲットRT5を通して受け取り、ディスク装置に書き込まれたユーザデータやメタデータはファイルサーバを通っていないから)。ローカルサイトとリモートサイトのそれぞれのファイルサーバ2にはFSキャッシュ18が存在し、それぞれデータを保存している。このため、従来の方式ではリモートサイトのFS処理が更新前のデータ内容を参照してしまい、クライアント6からのファイルへの参照を正しく処理することができない。

[0043]

そこで、本発明の実施形態においては、リモートサイトで正しくファイルへの参照を行えるように、図4に示す3つの構成要素、即ち、メタデータ更新監視部、メタデータ更新部、FSキャッシュパージ部、をリモートサイトのFS処理部17に設けることによって、正しいファイル参照を処理できるようにする。

[0044]

メタデータ更新監視部51は、リモートサイトのディスク装置3に対してファイルの更新が発生したことを検知するための構成要素である。この検知は、例えばディスク装置3内のジャーナルログ領域への書き込みを監視することによって行うことが可能である。ジャーナルログは、図9に示したようにある一定のログデータ領域93をラップアラウンドして使用している。このため、この領域内で次にどこにジャーナルログを書き込むかを示すポインタである終点ポインタ92を持っている。ディスク内の終点ポインタ92を定期的に読み出し、その値に更新があったことによって、ファイルの更新、即ちメタデータの更新が発生したことを知ることができる。

[0045]

メタデータ更新部52は、メタデータ更新監視部51によってファイルの更新、即ちメタデータの更新が発生したことを検知した場合に、更新に対応してFSキャッシュ18のメタデータを更新する構成要素である。図5に示すフローの通り、ローカルサイトでメタデータのディスク装置3への更新は、クライアント6からの書き込み要求と同期しては行われない。このため、リモートサイトでディスク装置3からメタデータの内容を読み出しても、更新前の内容を読み出してしまう可能性がある。そこで、メタデータ更新部52は、ジャーナルログを使用してメタデータの更新を行う。ジャーナルログにはローカルサイトで行われたメタデータの更新内容が記録されているため、これを用いることによりメタデータを更新後の状態にすることが可能である。

$[0\ 0\ 4\ 6]$

FSキャッシュパージ部53は、FSキャッシュ18内のユーザデータを廃棄するための構成要素である。メタデータ更新部52により更新されたメタデータに対するファイルは、ローカルサイトで書き込みがあったファイルであり、FSキャッシュ18上に保持されているこのファイルのユーザデータは、更新前の値である可能性がある。FSキャッシュパージ部53により、更新前のFSキャッシュ18上のデータを廃棄にすることにより、今後リモートサイトでクライアント6から参照要求があった場合に、ディスク装置3から更新後のユーザデータがFSキャッシュ18上に読み出され、参照することが可能となる。

[0047]

図7にファイル更新があった場合に、FSキャッシュ18の内容を正しく反映させるために、リモートサイトのFS処理部17の上記3つの構成要素(メタデータ更新監視部、メタデータ更新部、FSキャッシュパージ部)が行う処理のフローを示す。まず、ステップ121でメタデータ更新監視部51によりメタデータ更新の発生を監視する。メタデー

タの更新が発生した場合はステップ122からステップ123に進む。ステップ123では、メタデータの更新内容をFSキャッシュ18内に反映させるために、メタデータ更新部52は更新のあったジャーナルログを読み出す。そしてステップ124で、ジャーナルログに格納されている内容からメタデータの内容を更新する。その後、ステップ125でFSキャッシュパージ部53により、更新されたメタデータより更新されたファイルのユーザデータ領域を識別し、ステップ126でFSキャッシュ18上にその領域に対するキャッシュエントリが存在する場合には、そのキャッシュエントリを廃棄する。

[0048]

ステップ124で更新を行ったメタデータは、リモートサイトのFSキャッシュ18内で変更のあったメタデータとして管理し、FSキャッシュ18上に保持しておく必要がある。これは、リモートサイトのディスク装置3内ではメタデータの更新が行われていないためである。FSキャッシュ18上のメタデータを無効にしてしまうと、ディスク装置3から更新前のメタデータが読み出されて使用されてしまう可能性がある。さらに、リモートサイトのディスク装置3に対しては、ローカルサイトとデータ内容を一致させるために、書き込み禁止であることがある。この場合、ステップ124で更新を行ったメタデータの内容はリモートサイトのFS処理部17からディスク装置3に書き込むことはできない。このため、ローカルサイトのディスク装置3でメタデータが更新され、それがリモートサイトのディスク装置3に反映されるまでFSキャッシュ18上に保持する。

[0049]

メタデータがディスク装置3上で更新されたことは、ジャーナルログ領域90の始点ポインタ91により知ることが可能である。メタデータの更新を行う元となったジャーナルデータが始点ポインタ91と終点ポインタ93の間に存在する間は、メタデータがディスク装置3上に反映されていない可能性がある。始点ポインタ91が更新され、元となったジャーナルデータが始点ポインタ91と終点ポインタ93の間から外れた場合は、始点ポインタ91の更新以前にローカルサイトでメタデータのディスク装置3への書き込みが行われており、メタデータの保持を解除することが可能となる。

[0050]

ステップ125および126で、キャッシュエントリを廃棄しても、リモートサイトでユーザデータが更新される前にリモートサイトのクライアント6から参照要求があった場合、再び更新前のユーザデータをFSキャッシュ18に読み出してしまう可能性がある。更新前のデータを読み出すことを防ぐため、ステップ125および126は、ユーザデータの更新が終了したのを確認してから行うか、ユーザデータの更新が終了するまでその領域に読み出しを行わないように待つ等の処理を行う必要がある。ユーザデータの更新終了の確認はジャーナルログにより行う。この際、FS処理部17がジャーナルログにユーザデータ更新の終了を示すログデータを書く必要がある。

$[0\ 0\ 5\ 1]$

また、コミット要求を伴うファイルシステムの場合、FSキャッシュパージ手段53が行うステップ125と126は、このコミット処理に対するジャーナルログを契機に行えばよい。

[0052]

尚、図7のステップ126においては、FSキャッシュ18上のキャッシュエントリを 廃棄した。しかし、リモートサイトのディスクキャッシュにはローカルサイトからリモートコピーされてきたユーザデータが格納されている。そこで更新されたメタデータに対応 するファイルのユーザデータがFSキャッシュ上に存在する場合には、当該ユーザデータ を廃棄する代わりに、FSキャッシュパージ部が、当該ファイルのユーザデータをディス クキャッシュから読み出して、FSキャッシュ上に格納しても良い。

[0053]

ここまでは、FS処理部17が処理するファイルシステムは、ジャーナルログを作成するジャーナリングファイルシステムである例を説明したが、FS処理部17が処理するファイルシステムは、ジャーナリングファイルシステムに限定されるわけではない。この場

合、リモートサイトのストレージシステム1内のメタデータ更新監視部51は、ディスクドライブへの更新が行われたことを監視することによりメタデータ更新が行われたことを認識する。メタデータ更新が行われたことを認識する方法としては、ディスク制御部内のリモートコピー部26からFS処理部17に割り込み等により通知する方法や、リモートコピー部26によりディスク装置3内の別のディスクドライブ23に更新があったこと、および更新のあったデータの格納位置を書き込み、それをFS処理部17が定期的に読み出し、その内容が更新されることによって認識する方法等が考えられる。

[0054]

メタデータ更新部52は、更新の行われたメタデータをFSキャッシュ18から廃棄するだけでよい。FS処理部17が処理するファイルシステムがジャーナルを用いないファイルシステムである場合、FS処理部17はディスク装置3へのメタデータの書き出しをクライアント6からの書き込み要求と同期して行う。このため、FSキャッシュ18から廃棄し、次回使用する必要が生じた時にディスク装置3から読み出すことによって更新後のメタデータを参照することが可能であるからである。また、FSキャッシュパージ部53は、メタデータ更新部52により廃棄されたメタデータに対応したユーザデータをFSキャッシュ18から廃棄すればよい。

[0055]

以上説明したように、本発明の実施形態に係るストレージシステムでは、リモートサイトのファイルシステムで、ファイル更新即ち、メタデータ更新を監視する更新監視部と、メタデータを更新する更新部、更新のあったファイルのFSキャッシュをパージするパージ部を有することによって、ローカルサイトでの更新が行われるのに合わせて、更新内容をリアルタイムにリモートサイトのファイルシステムに反映させ、リモートサイトで最新のファイルデータを参照することを可能とするものである。

【図面の簡単な説明】

[0056]

【図1】本発明の実施形態に係るストレージシステムの全体構成を示すブロック図である。

【図2】本実施形態のストレージシステムをリモートコピー接続した統合システム構成例を示す図である。

【図3】ローカルサイトとリモートサイトのストレージシステム間でのデータ転送及 びリモートサイトにおける最新ファイルデータの参照の状況を示す図である。

【図4】本実施形態で使用するファイルサーバ内のファイルシステム処理部における 機能を示す図である。

【図 5】ローカルサイトのストレージシステムへのファイル書き込み要求に対するファイル処理部の処理フローを示す図である。

【図 6 】ストレージシステムのディスク装置に書き込みが行われた場合におけるディスク制御部の実行するリモートコピーの処理フローを示す図である。

【図7】ファイル更新があった場合のリモートサイトストレージシステムにおけるファイルシステム処理部が実行する複数処理のフローを示す図である。

【図8】リモートコピーを行う際のリモートサイトに転送されるリモートコピーデータの構成例を示す図である。

【図9】ディスク装置内のディスクドライブに存在するジャーナルログ領域の格納情報を示す図である。

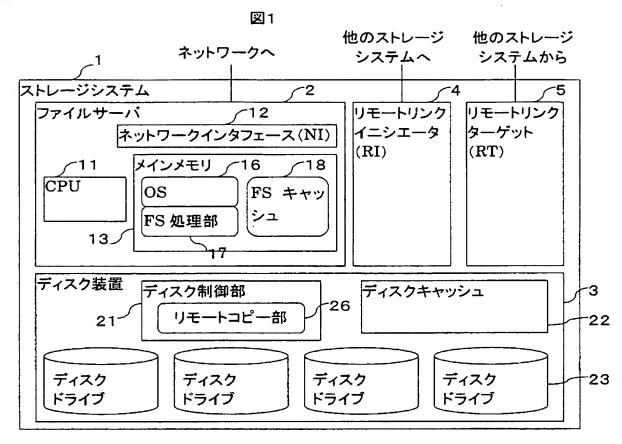
【符号の説明】

[0057]

- 1 ストレージシステム
- 2 ファイルサーバ
- 3 ディスク装置
- 4 リモートリンクイニシエータ
- 5 リモートリンクターゲット

- 6 クライアント
- 7 ネットワーク
- 8 通信回線
- 11 CPU
- 12 ネットワークインタフェース (NI)
- 13 メインメモリ
- 16 OS
- 17 FS (ファイルシステム) 処理部
- 18 FSキャッシュ
- 21 ディスク制御部
- 22 ディスクキャッシュ
- 23 ディスクドライブ
- 26 リモートコピー部
- 33, 34 FSキャッシュ
- 37, 38 クライアント
- 40,47 FSキャッシュ内メタデータ
- 41,48 FSキャッシュ内ユーザデータ
- 42,49 FSキャッシュ内ジャーナルログ
- 43,45 ディスクキャッシュ内ユーザデータ
- 44,46 ディスクキャッシュ内ジャーナルログ
- 51 メタデータ更新監視部
- 52 メタデータ更新部
- 53 FSキャッシュパージ部

【書類名】図面【図1】



【図2】

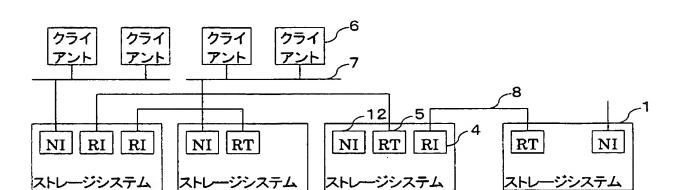
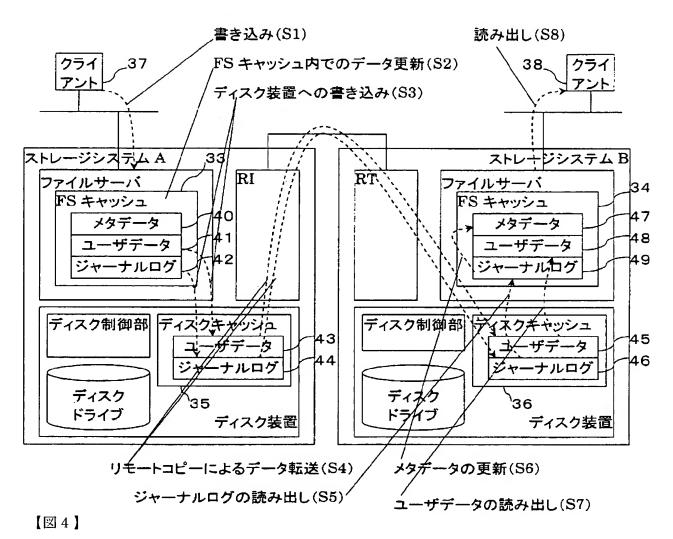


図2

[図3]

図3



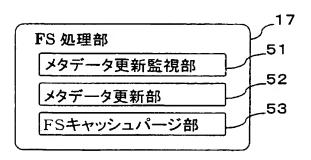
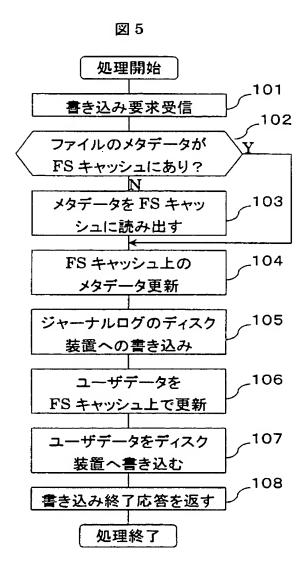
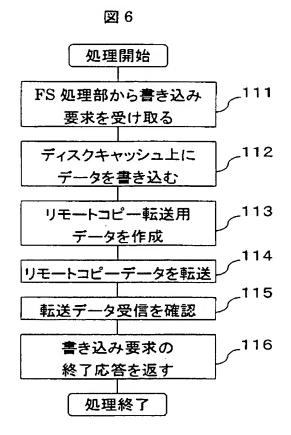


図4

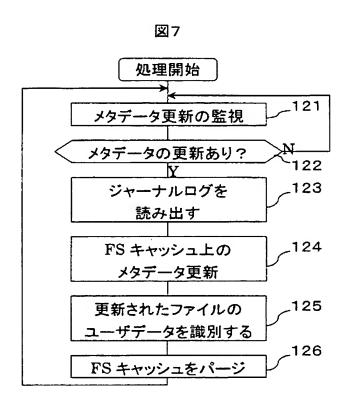
【図5】



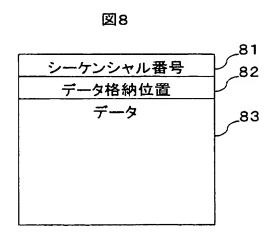
【図6】



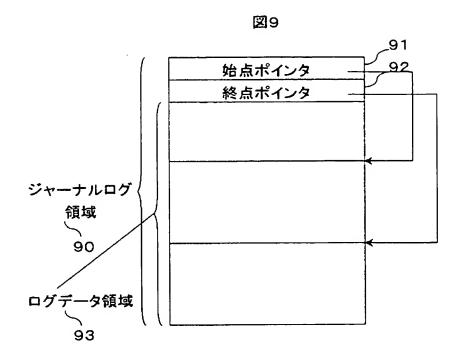
【図7】



【図8】



【図9】



【書類名】要約書

【要約】

【課題】リモートコピーを行うストレージシステムにおいて、ローカルサイトでの更新が行われるのに合わせて、更新内容をリアルタイムにリモートサイトのファイルシステムに反映させて最新のファイルデータを参照可能とすること。

【解決手段】ディスクドライブ、ディスク制御部、ディスクキャッシュ、を有するディスク装置と、CPU、メインメモリ、を有するファイルサーバと、通信回線を介して他のストレージシステムAのディスク装置とデータを授受するインタフェースと、を備えたストレージシステムBであって、ディスク装置内のファイルの管理情報履歴46を参照し、他のストレージシステムで行われたファイル更新に対応してファイルサーバにおけるファイルの管理情報47を更新し、ストレージシステムに接続されたクライアントからの読み出し要求に対して更新後のユーザデータ48を転送することを可能とする構成である。

【選択図】図3

特願2003-364793

出願人履歴情報

識別番号

[000005108]

1. 変更年月日

1990年 8月31日

[変更理由]

新規登録

住 所

東京都千代田区神田駿河台4丁目6番地

氏 名

株式会社日立製作所